

딥러닝과 STFT 신호 분석을 활용한 EMB 시스템 고장 예측에 관한 연구

노 은 정* · 김 만 기 · 원 종 익 · 박 재 현 · 지 현 · 고 상 진 · 정 지 현

HL 만도 SW 캠퍼스

A Study on Fault Prediction in EMB Systems Using Deep Learning and STFT Signal Analysis

Eunjung No* · Mangi Kim · Jongick Won · Jaehyun Park · Hyun Jee · Sangjin Ko · Jihyun Jung

SW Campus, HL Mando, 255 Pangyo-ro, Bundang-gu, Seongnam-si, Gyeonggi 13486, Korea

(Received 30 October 2024 / Revised 27 January 2025 / Accepted 31 January 2025)

Abstract : This study focused on a prognostics and health management(PHM) system to predict a specific fault in the electric mechanical brake system. As software requirements become increasingly complex, implementing a robust PHM system is essential to ensure reliability and safety. This research systematically categorized fault conditions and extracted key features from signal data using fast Fourier transform techniques to generate short-time Fourier transform spectrogram image data sets. A univariate ResNet model was trained using motor phase-U voltage data, achieving a fault classification accuracy of 83.08 %. Notably, the model effectively differentiated between normal and fault states, even under dynamic driving conditions. This research underscored the potential to minimize maintenance requirements and enhance system reliability, contributing to safer and more efficient operation of the EMB system in real-world scenarios. To supplement the current study's findings, future research exploring strategies on how to improve model accuracy by integrating multi-channel data and applying state-of-the-art convolution neural network(CNN) architectures is recommended.

Key words : Electro mechanical brake(전기 기계식 브레이크), Prognostics and health management(고장 예지 및 건전성 관리), Short-time fourier transform(단시간 푸리에 변환), Convolutional neural network(합성곱 신경망), Brake by Wire(브레이크 바이 와이어)

1. 서 론

자동차 산업에서 소프트웨어의 복잡성이 증가하면서 차량의 안전성과 승차감에 대한 기대와 요구가 더욱 높아지고 있다. 이에 따라 차량 내 다양한 새시 제어 시스템이 도입되면서 기존 유압식 브레이크 시스템은 응답 속도와 같은 성능적인 측면뿐만 아니라 복잡한 제조 공정과 같은 환경적인 측면에서도 한계를 드러내고 있다. 이러한 문제를 해결하기 위한 대안으로 Brake-by-Wire(BbW) 시스템이 주목받고 있다.^{1,2)}

BbW 시스템은 부스터, 마스터 실린더, 유압 유닛과 같은 기존 유압 부품 대신 전기모터로 구동되는 액추에이터를 사용하며 기계적인 작동 원리를 이용하여 제동

하는 브레이크이다. 유압식 브레이크와 달리브레이크액이 필요 없기 때문에 유지보수가 간소화 되며 친환경적인 장점을 제공한다. 브레이크 액 주입 공정을 생략함으로써 자동차 조립 라인의 공정이 단순화되어 생산 원가 절감 효과를 기대할 수 있다. 또한, BbW 시스템은 각 휠에서 브레이크 액추에이터의 제동력을 독립적으로 제어할 수 있기 때문에 제어 유연성이 뛰어나며 회생 제동 시스템 및 운전자 보조 기능과의 통합이 가능 할 것으로 기대된다.

그러나 BbW 시스템 도입의 확대 전망에 따라 전기모터와 기계적 부품이 결합된 복잡한 제어 시스템의 고장 발생 가능성에 대한 우려도 함께 증가하고 있다. 이러한

*Corresponding author, E-mail: eunjung.no@hlcompany.com

[†]This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium provided the original work is properly cited.

고장은 차량 안전성에 직접적인 영향을 미치기 때문에 고장 예측 및 Redundancy의 필요성이 부각된다.³⁾

이를 해결하기 위한 방안으로 Prognostics and Health Management(PHM) 시스템이 중요한 역할을 한다. PHM 시스템은 다양한 센서와 데이터를 기반으로 차량 부품의 상태를 모니터링하고 고장 가능성을 사전에 예측함으로써 차량의 안전성과 운영 효율성을 크게 향상시킨다. 이를 통해 차량의 유지보수 비용 절감 및 다운타임을 최소화할 수 있다.⁴⁾

기존 연구에서는 진동 센서 혹은 음향 센서와 같은 외부 센서를 추가하여 고장을 검출하는 CNN 기반의 딥러닝 기술 개발이 활발히 이루어졌다.^{5,6)} 대부분 높은 정확도를 보이지만 실제 환경이 아닌 제한된 환경에서 데이터를 수집하고 고장을 검출했기 때문에 실제 산업 적용에는 어려움이 있었다. 이후 비용 절감을 위해 시스템의 전류 값을 이용해 고장을 검출하는 시도가 이어졌으나 외부 센서를 부착하여 고장을 검출하는 방법에 비해 현저히 낮은 정확도를 보인다. 따라서 실제 운영 환경에서 수집된 데이터를 기반으로 훈련 데이터를 생성하는 것이 더욱 중요해졌으며 외부 센서를 사용하지 않는 경우에는 원시 데이터의 적절한 전처리를 통해 정확도를 높이는 노력이 필요하다.^{7,8)}

본 연구의 목표는 실 데이터를 기반으로 훈련 데이터를 수집하고 차량 산업에 적용 가능한 신뢰성 평가 기반 PHM 시스템을 구축하는 것이다. 이를 위해 외부 센서를 사용하지 않고 시스템 신호를 활용하여 FFT 및 STFT 분석 기법을 적용한다. FFT는 시스템의 고유 주파수 특성을 확인하기 위한 방법으로 사용되며, STFT는 시간에 따라 변동하는 신호 특성을 분석하는 데 활용된다.⁹⁾ 이를 통해 시간-주파수 특징을 시각화한 Spectrogram을 추출하고, Convolutional Neural Network(CNN)의 입력 데이터로 활용한다.

본 연구에서는 HL Mando Drum-Electro Mechanical Brake(D-EMB) 제품의 내구 테스트를 통해 주요 고장의 원인으로 판단 되는 요소 부품인 벨트의 불량을 검출하고, 고장의 심각도 단계를 분류하는 신호 특징 분석 방법 및 딥러닝 모델을 제안한다. 이를 통해 EMB 제품의 PHM 시스템 구축을 위한 기반을 마련하고자 한다. 2장에서는 고장 예측 모델에 대한 개발 방법론에 대해 간단히 기술한다. 3장에서는 데이터 계측 방법과 수집 데이터에 대해 소개하며 시스템의 주파수 분석 결과에 대해 설명한다. 그 다음 데이터 전처리 과정을 통해 신호 Spectrogram 이미지 데이터를 생성하고 이를 바탕으로 고장 예측 모델을 학습한다. 4장에서는 테스트 데이터를 바탕으로 모델을 검증한다. 마지막으로 5장에서는 연구

결과와 기대 효과를 논의하고 향후 연구 개발 계획에 대해 기술한다.

2. Materials and Methods

2.1 Fast Fourier Transform(FFT)

푸리에 변환(Fourier Transform)은 임의의 입력 신호를 다양한 주파수를 갖는 주기함수들의 합으로 분해하여 표현하는 기법이다. 푸리에 변환에서 사용하는 주기 함수는 사인(Sine)과 코사인(Cosine) 삼각함수이며 고주파부터 저주파까지 다양한 주파수 대역의 주기 함수들로 원본 신호를 분해한다. 푸리에 변환의 기본 원리는 식 (1)과 같이 오일러 함수(Euler's Formula)를 통해 삼각함수를 복소지수함수로 나타내는 것이다. 이를 통해 푸리에 변환에서 함수 $x(f)$ 를 식 (2)와 같이 간단하게 표현할 수 있다.

$$\begin{aligned} e^{j\theta} &= \cos\theta + j \sin\theta \\ e^{j2\pi ft} &= \cos(2\pi ft) + j \sin(2\pi ft) \end{aligned} \quad (1)$$

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt \quad (2)$$

여기서 $x(t)$ 는 원본 입력 신호인 연속 시간 함수, $e^{-j2\pi ft}$ 는 주파수 f 인 주기 함수 성분, $X(f)$ 는 해당 주기 함수 성분의 계수(Coefficient)를 나타낸다. 푸리에 변환을 사용하면 시간과 주파수 관계를 일정한 주기로 나타낼 수 있어 신호를 분석하는데 효과적이지만 시간에 따른 주파수 변화를 반영하지 못하는 한계가 있다. 즉 신호의 시간적 변화는 고려되지 않기 때문에 짧은 시간 동안 발생하는 순간적인 변화나 고주파 성분이 포함된 신호에서는 특정 신호 특성을 제대로 분석하지 못할 수 있다.

본 연구에서는 정차 상태의 일정 부하 토크 시험 데이터를 기반으로 FFT 분석을 수행해 정상 및 고장 상태에서 주파수 특성을 확인한다. 그 다음 주파수 특성 변화가 두드러지는 신호를 선정하여 주행 데이터를 기반으로 고장 검출을 수행한다.

2.2 Short-Time Fourier Transform(STFT)

Short-Time Fourier Transform(STFT)은 신호를 시간과 주파수 영역에서 분석하는 기법이다. Fig. 1과 같이 윈도우 함수를 사용하여 신호를 짧게 나누고 각 구간에 대해 푸리에 변환을 적용하여 시간에 따른 주파수 변화를 확인한다.

STFT의 윈도우 함수는 식 (3)과 같이 정의 된다. 윈도우 함수 $w(t)$ 는 중심점(τ_0)로 이동하고 원본 입력 신호




Fig. 1 The window function of short-time Fourier transform

$x(t)$ 에 곱하여 짧은 구간으로 나뉜 신호 $y(t)$ 를 얻는다.

$$y(t) = x(t)w(t - \tau_0) \quad (3)$$

각 구간에서 푸리에 변환을 수행하고 이를 통해 신호의 시간과 주파수 정보를 모두 포함한 Spectrogram을 생성할 수 있다. STFT의 수식은 식 (4)와 같이 표현된다.

$$\begin{aligned} X(w) &= F(y(t)) = \int_{-\infty}^{\infty} x(t)w(t - \tau_0)e^{-j2\pi ft} dt \\ S(\tau, w) &= F(x(t)w(t - \tau)) \\ &= \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j2\pi ft} dt \end{aligned} \quad (4)$$

여기서 $w(t - \tau)$ 는 중심점 τ 로 이동한 윈도우 함수이며 푸리에 변환을 통해 얻어진 주파수 성분 $S(\tau, w)$ 는 시간과 주파수 정보를 동시에 제공한다. 이때 윈도우 크기가 너무 작으면, 주파수 영역의 해상도가 떨어지고 시간 영역 해상도는 올라간다. 반대로 윈도우 크기가 너무 크면, 반대로 주파수 영역 해상도는 올라가지만 시간 영역 해상도가 떨어진다.

윈도우 함수의 종류로는 Hanning 윈도우를 주로 사용하며 아래 식 (5)는 Hanning 윈도우의 수학적 표현식이다.

$$w(n) = 0.5 \left(1 - \cos \left(\frac{2\pi n}{N-1} \right) \right), \quad 0 \leq n \leq N-1 \quad (5)$$

여기서 N 은 총 샘플 수 이고 n 은 샘플 인덱스이다. Hanning 윈도우는 종모양의 곡선으로 푸리에 분석을 수행하기 전에 신호에 적용하여 짧은 구간으로 나뉘어진 신호의 끝이 0으로 부드럽게 전환되도록 함으로써 누설 (Spectral Leakage)현상을 줄이고 Spectrum 분석의 품질을 향상시킨다. 이러한 주파수와 시간의 Trade off 관계로 인한 Resolution의 한계를 완화시키기 위해 중첩 (Overlap)방법을 사용한다.

STFT는 FFT 대비 계산 복잡성이 높지만 시간에 따라

고장 주파수 대역이 변하는 상황, 짧은 시간 단위에 일 시적 결함을 포착하는 데 적합하다. 따라서 본 연구에서는 부하 또는 토크가 가변적인 차량 시스템의 주행 데이터를 Spectrogram으로 생성하는 도구로 STFT를 활용한다.

2.3 Fault Diagnostic Method

본 연구에서 제안한 EMB 시스템의 고장 예측 모델 전체 프로세스는 Fig. 2와 같다.




Fig. 2 Flow chart of belt fault diagnostic method

1. 결함 데이터 수집 및 검증을 위해 인위적으로 결함을 발생시키고 샘플을 확보한다.
2. 수집된 시스템 신호를 푸리에 변환을 통해 분석하고 고장 예측 모델 학습에 사용할 신호를 선정한다. 선정된 1D 데이터를 STFT 분석을 통해 Spectrogram으로 변환한다.
3. 생성된 Spectrogram 이미지 데이터를 정규화하고 일정 비율에 따라 훈련, 검증, 테스트 세트로 나눈다.
4. 딥러닝 모델을 선정하고 학습을 진행한다.
5. 훈련 모델을 EMB 시스템 시험 차량에 적용하여 차

량의 정상 및 고장 상태를 예측하고 고장의 심각도를 분류한다.

6. 고장 심각도 분류 결과에 기반하여 차량의 상태에 따른 EMB 시스템 독립 제어를 수행한다.

본 연구에서는 CNN의 대표 모델인 ResNet을 활용하여 고장 예측을 위한 딥러닝 모델을 학습한다. ResNet 모델은 깊은 네트워크 구조에도 불구하고 효과적인 정보 전달을 가능하게 하는 잔차 학습을 통해 높은 정확도를 보장하지만 복잡한 구조로 인해 상대적으로 긴 학습 시간이 소요될 수 있다.¹⁰⁾ 모델은 사전 학습된 가중치를 사용하여 초기화하며 마지막 레이어는 3개의 클래스를 분류하도록 수정한다.

모델의 최종 출력 단계에서 고장 심각도를 분류하는 목적은 차량의 안전성과 신뢰성을 보장하기 위한 사전 예지를 구현하기 위해서다. 차량 환경에서 발생할 수 있는 위험 상황을 미리 인지하게 되면 고장 심각도에 따라 제어 전략을 구현할 수 있다. 이를 위해 본 연구에서는 Diagnostic Trouble Code(DTC) 발생 이전 단계에서 인위적으로 시스템 결함을 발생시키고 심각도 단계를 구분하여 이를 예측하고자 한다.

Fig. 3은 Safety Control Mechanism 발생 상황의 간단한 예시이다. PHM 솔루션 개발을 통해 사전 고장을 감지하면 시스템의 Redundancy 확보를 위한 제어 안전 메커니즘을 구현할 수 있다.

System status	Normal	Fault severity Lv.1	Fault severity Lv.2	DTC
Driving Feasibility	Feasible	Feasible	Feasible	Inspection needed
System Response	-	Safety mechanism		Fleet Maintenance
Driver Discomfort	-	Minimal	Slight Discomfort	Driving Not Possible

Fig. 3 Safety control framework for vehicle systems

예를 들어 2개의 Rear 휠 중 하나의 휠에서 성능 저하가 발생했을 때 나머지 3개의 휠에 제동 성능을 재분배함으로써 차량 전체의 안전한 제동 성능을 확보할 수 있다.

3. Experimental Methodology

3.1 Data Acquisition

PHM 시스템 개발을 위해서는 고장이 발생할 때까지 제품을 사용하는 동안의 전체 운영 과정을 모니터링한 연속적인 시간 데이터를 사용하는 것이 가장 이상적이다. 하지만 이러한 데이터는 수집에 오랜 시간이 소요되기 때문에 본 연구에서는 인위적으로 EMB 시스템의 벨

트 결함을 생성하여 정상 작동 조건, 심각도 1차, 심각도 2차에 대한 비연속적인 시간 데이터를 수집한다. 심각도 1차 샘플은 벨트의 장력을 정상 샘플 대비 약 46% 감소시켜 조립하고 심각도 2차 샘플은 벨트의 장력을 약 75% 감소시켜 조립한다.

조립된 EMB 결함 샘플을 Fig. 4와 같이 시험 차량의 후륜 우측(RR, Rear Right)에 순차적으로 장착하고 Fig. 5와 같이 환경을 구성한다. 수집하는 데이터는 Table 1에 정의된 시스템 관련 변수인 클램핑 힘 센서(Clamping force sensor), 모터 위치 센서(Motor position sensor), 모터 Idq 전류(Motor Idq current), 모터 위상-UV 전압(Motor phase-UV voltage), 차량 속도(Vehicle speed) 등을 수집한다.




Fig. 4 Process of installing fault samples in the vehicle




Fig. 5 Configuration of test vehicle set-up

Table 1 Dataset

Signal definition	Signal definition
Data log time [s]	Motor position sensor [mm]
Battery voltage [V]	Motor torque [Nm]
Wheel speed [kph]	Motor id current [A]
Vehicle speed [kph]	Motor iq current [A]
Reference clamping force [N]	Motor phase-U voltage [V]
Measured clamping force [N]	Motor phase-V voltage [V]

시험 조건은 Table 2에 명시된 두 가지 방법으로 진행된다. 첫 번째는 정차 상태에서 CANoe 장비에서 제공하는 IG(Interactive generator) Block을 이용하여 주기적으로 동일한 Trapezoid 파형의 Clamping Force Reference를 입력하는 방법, 두 번째는 차량 속도 30 ~ 60 kph의 주행 조건에서 운전자 페달링을 통해 무작위로 Clamping Force Reference를 입력하는 방법이다. 두 조건 모두 시스템 피드백 제어 상태에서 데이터를 계측하며 시간 샘플링 주기는 8 ms이다.

최종적으로 수집된 데이터의 형태는 Fig. 6과 같다. 정차 조건에서는 Trapezoid 파형을 각 샘플에 대해 200회씩 인가하여 총 3개의 샘플에서 600개의 데이터 세트를 수

Table 2 Conditions for collecting data

Condition	Input method	Clamping force
Stationary (0 kph)	CANoe IG Block (Trapezoid Waveform)	Periodic 2500 N
Driving (30-60 kph)	Pedal	1000 N ~ 8000 N




Fig. 6 Collected data(legend : — Reference clamping force[N])

집하고, 주행 조건에서는 Level 1과 Level 2 차량 각각을 10분 동안 20회씩 주행하여 40개의 데이터 세트를 수집한다.

3.2 Data Analysis

본 연구에서는 FFT분석을 통해 시스템의 주요 신호인 Clamping force sensor, Motor position sensor, Motor Idq current, Motor phase-UV voltage 등의 고장 상태에 따른 주파수 특성을 평가한다.

Fig. 7은 심각도 1차 및 2차 샘플의 FFT 분석 그래프이며, 정상 신호와 결함 신호 간의 주파수 Spectrum 차이를 비교한 것이다.

Fig. 7(a), (b)는 Motor phase-UV voltage 신호이다. 심각도 1의 경우 0.2 Hz 이하의 대역에서 정상 대비 10 % 이상의 높은 진폭을 보인다. 반면 심각도 2의 경우 0.2 Hz 이하의 대역에서 정상 대비 높지 않은 진폭을 보이지만 주로 2 Hz부터 8 Hz 구간에서 고주파 성분이 증가하였다. 또한 심각도 2의 Motor phase-U voltage 신호는 0.3998 Hz, 0.5998 Hz에서 새로운 피크가 발생한다. 이는 심각도 1차 샘플 대비 고장이 심화되면서 모터 내부의 비선형적인 자기적 포화, 기계적 마모, 또는 진동에 의해 고주파 성분이 증가하고 저주파 성분은 상대적으로 감소한 것으로 보인다.

Fig. 7(c) Clamping force sensor와 Fig. 7(d) Motor position sensor 신호는 정상 샘플과 고장 샘플 간 주파수 대역에서 큰 차이를 보이지 않았으나 결함의 심각도에 따라 진폭이 소폭 감소한다. Fig. 7(e), (f)인 Motor Idq current 신호에서는 심각도 1의 경우 결함으로 발생한 시스템 오차를 보상하기 위해 모터 전류가 증가하면서 5 Hz이하 대역에서 진폭이 증가하였다.

반면 심각도 2의 경우 5 Hz이하의 대역에서는 진폭이 감소하고 5 Hz이상의 대역에서 진폭이 증가한다. 이를 통해 결함이 심화될수록 모터가 5 Hz 이상의 고주파 성분에 더 큰 영향을 받는다는 것을 확인하였다. 저주파 성분의 감소는 결함 상태에서 모터의 전류 제어가 비효율적으로 작동하면서 저주파 에너지가 고주파로 이동하는 것으로 보인다.

결론적으로 결함의 심각도에 따라 가장 두드러지는 주파수 특성의 변화를 보이는 Motor phase-U voltage 신호를 기반으로 단변량 STFT와 CNN을 결합한 고장 예측 모델 학습을 진행한다.




Fig. 7 Frequency spectrum analysis using fast FFT(legend : ● baseline, ■ severity level 1 and ▲ severity level 2), data : stationary)




Fig. 8 Spectrogram generated from the result of STFT (data: driving & motor phase-U voltage)

3.3 Data Processing

PHM 시스템은 시간에 따른 시스템 성능 저하를 검출하기 위해 STFT를 사용하여 신호를 시간 구간별로 나누고 주파수를 분석한다. Hanning 윈도우의 크기를 300로 설정하고, 50 %의 Overlap을 적용하여 시간 도메인에서 신호를 나눈 후 FFT를 수행한다. 통상적으로 신호의 시간 및 주파수 분해능 사이의 균형을 잘 맞출 수 있도록 50 %의 Overlap을 사용한다.

Fig. 8는 Motor phase-U voltage의 STFT Spectrogram으로 시스템 상태 별 시간에 따른 주파수 변화를 시각적으로 보여준다. 진폭이 클수록 블록은 밝아지고 진폭이 작을수록 어두워진다. 이러한 시각적 변화는 고장 발생 시점에서의 주파수 특성을 명확히 나타내기 때문에 고장 여부를 쉽게 구분할 수 있다. 다수의 신호를 활용하여 다중 채널 데이터를 생성하면 인식의 정확도를 높일 수 있지만 본 연구에서는 단일 채널 데이터만 활용한다.

최종적으로 Spectrogram 이미지는 Min-max Normalization과 L2 Regularization 함수로 정규화되며 ResNet 모델의 입력에 맞게 형태를 변환한다. 마지막으로 데이터를 60 %, 20 %, 20 %의 비율로 나누어 훈련, 검증, 테스트 데이터 세트를 구성한다.

3.4 Model Training

본 연구에서는 주행 조건에서 수집한 데이터를 활용하여 학습을 진행한다. 정차 조건의 데이터로 학습하는 경우, 고장 샘플의 수가 한정적이며 제한된 환경에서의 실험이기 때문에 오버피팅으로 인한 과도하게 높은 정확도가 나타날 수 있다. 따라서 고장 샘플에 대한 일반화 성능을 개선하기 위해 주행 테스트 결과를 기반으로 학습을 진행한다. 이 접근 방식은 실제 환경에서의 데이터 분포를 반영하여 주행 중에도 고장 상황을 예측할 수 있도록 한다.

학습은 Windows 10 64-bit 운영체제에서 Intel Core i7 프로세서와 NVIDIA Tesla T4 GPU를 사용하여 진행되며 CUDA 12.2 환경에서 수행된다. 학습 데이터는 100 epochs 동안 훈련되며 K-Fold 교차 검증 방법을 적용하여 k=5로 설정한다. 각 폴드에서 훈련 손실 및 정확도를 기록하고 최종적으로 평균 성능을 평가한다. 손실 함수로는 Cross Entropy 손실 함수를 사용하여 각 클래스 간의 오차를 계산하고 계산식은 아래 식 (6)과 같다.

$$Loss = \frac{1}{n} \sum_i \sum_{c=1}^m y_{ic} \log(p_{ic}) \quad (6)$$

4. Results and Discussion


정확도(Accuracy)는 신경망 모델의 성능을 평가하는 주요 지표 중 하나로 입력된 샘플 중 올바르게 예측된 비율로 정의된다. 계산식은 식 (7)과 같다.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$


여기서 FP(False Positive)는 잘못 예측된 카테고리의 수, TP(True Positive)는 올바르게 예측된 카테고리의 수, TN(True Negative)는 다른 카테고리에서 올바르게 예측된 수, FN(False Negative)는 다른 카테고리에서 잘못 예측된 수를 나타낸다. 정확도가 높을수록 모델이 데이터의 다양한 패턴을 잘 학습했음을 나타낸다.

최종 모델 성능을 비교한 결과는 Fig. 9와 Table 3과 같다. Min-max 정규화를 적용한 모델의 평균 학습 정확도는 98.22 %이고 평균 검증 정확도는 81 %이다. L2 정규화를 적용한 모델의 평균 학습 정확도는 98.53 %이고 평균 검증 정확도는 83.08 %로 Min-max 대비 L2 정규화 모델의 정확도가 2.08 % 더 높다. L2 정규화는 가중치를 축소하여 모델의 복잡성을 줄이고 과적합을 방지함으로써 검증 데이터에 대한 일반화 성능을 향상시킨다.

다음으로 테스트 데이터를 이용하여 L2 정규화를 적



(a) Train loss and valid loss



(b) Train accuracy and valid accuracy

Fig. 9 Training results

Table 3 Final accuracy based on ResNet(data : driving)

Hyper parameter	Scaler	Val Loss	Val Acc
w_len = 300 hop_size = 150 Fs = 125 num_epochs=100 batch_size=64 k=5	Min-max normalization	0.663	81.0
	L2 regularization	0.577	83.08

용한 모델의 일반화 성능을 평가하였다. Fig. 10은 혼동 행렬(Confusion Matrix) 결과로 각 카테고리에 대한 분류 정확도를 시각적으로 나타내며 대각선 요소는 각 카테고리에서 올바르게 예측된 비율을 보여준다. 대각선 외 요소는 서로 다른 카테고리 간의 오분류를 나타낸다. 정상 클래스에서 82 %는 정확하게 정상으로 분류된다. 벨트 고장 1단계 클래스와 벨트 고장 2단계 클래스에서는 79 %가 정확하게 분류되었다. 각 클래스에서 인접한 클래스로 오분류하는 비율은 15 % 정도이다. 이를 통해 정상과 심각한 고장 상태 간의 오분류 비율이 낮고 주요 상




Fig. 10 Confusion matrix

태를 명확히 구분할 수 있다는 것을 확인하였다.

Fig. 11은 ROC(Receiver-Operating Characteristic Curve) 결과이다. ROC 커브의 면적(AUC, Area Under the Curve)은 클래스를 구별하는 모델의 성능 지표로 사용되며 1.0에 가까운 값일수록 분류 성능이 우수함을 나타낸다. 정상 클래스의 AUC는 0.93, 벨트 고장 1단계 클래스의 AUC는 0.90, 그리고 벨트 고장 2단계 클래스의 AUC는 0.97로 나타났다. Micro-average AUC는 데이터 불균형이 존재하는 경우에도 모델의 전체 성능을 종합적으로 평가할 수 있는 지표로 0.90으로 나타났다. 이는 모든 클래스에서의 예측 결과를 통합하여 계산한 값이다. Macro-




Fig. 11 Receiver-operating characteristic curve(ROC)

average AUC는 각 클래스의 ROC-AUC 값의 평균으로 0.93으로 나타났다. 이는 각 클래스의 성능을 독립적으로 평가하여 평균을 내는 방식으로 데이터의 균형 여부와 관계없이 클래스 간 성능을 비교할 수 있다. 전반적으로 분류 성능이 우수하며 특히 클래스 2에서 높은 분류 성능을 보인다. 이를 통해 모델이 정상 상태와 벨트 고장 상태를 효과적으로 구별할 수 있음을 알 수 있다.

5. Conclusion

본 연구에서는 FFT 기법을 적용하여 EMB 시스템에서 벨트의 고장이 발생했을 때 나타나는 시스템 주파수 특성에 대해 분석하고, STFT 기법을 활용하여 고장 심각도를 분류하기 위한 Spectrogram 이미지를 생성하였다. 이러한 이미지 학습 데이터를 기반으로 ResNet 모델을 적용하여 시스템의 고장 심각도를 예측하는 방법을 제안하였다. 특히 본 연구는 정적 환경뿐만 아니라 동적 환경에서의 성능 향상을 목표로 하여 주행 데이터를 활용하여 학습을 진행하였다. 이를 통해 실제 차량 환경에서 적용할 수 있는 일반화 성능의 개선 가능성을 확인하였다. 다만 모델의 성능을 더욱 향상시키기 위해 추가적인 개선이 필요하다.

향후 연구에서는 다중 채널 데이터 적용을 위해 다수의 신호를 통합하고 최신 State-of-the-Art(SOTA) CNN 모델을 활용하여 학습 효율성과 예측 정확성을 높일 예정이다. 또한 주행 데이터를 추가로 수집하여 모델의 일반화 성능을 강화할 예정이다. 더 나아가 내구 테스트를 통해 고장 발생 가능성이 높은 케이스를 확대 적용하여 PHM 시스템의 인식률을 향상시키고, 실제 시스템 제어 활용 프로세스와의 연계를 통해 실시간 모니터링 및 피드백 체계를 구축할 것이다. 이러한 과정을 통해 본 연구에서 제안한 모델이 실제 환경에서 안전하고 효과적인 차량 관리 시스템으로 활용될 수 있기를 기대한다.

Acknowledgements

본 연구는 2024년도 산업통상자원부 및 산업기술기회평가원(KEIT)의 연구비 지원에 의해 수행되었음(RS-2024-00402701).

References

- 1) X. Gong, W. Ge, J. Yan, Y. Zhang and X. Gongye, "Review on the Development, Control Method and Application Prospect of Brake-by-Wire Actuator," *Actuators*, Vol.9, No.1, p.15, 2020.
- 2) J. S. Cheon, J. Kim and J. Jeon, "New Brake-by-

- Wire Concept with Mechanical Backup,” SAE 2012-01-1800, pp.1194-1198, 2012.
- 3) H. C. Schlimme and R. Henze, “Brake-by-Wire System Redundancy Concept for the Double Point of Failure Scenario,” SAE 10-07-03-0021, pp.329-341, 2023.
- 4) A. Glowacz, “Fault Diagnosis of Single-Phase Induction Motor Based on Acoustic Signals,” Mechanical Systems and Signal Processing, Vol.117, pp.65-80, 2019.
- 5) D. Zhang and T. Zhou, “Deep Convolutional Neural Network Using Transfer Learning for Fault Diagnosis,” IEEE Access, Vol.9, pp.43889-43897, 2021.
- 6) G. Choi, I. -S. Chang, Y. Lee, H. Kang and G. Park, “Fault Detection of Motor Gear Box Using Two Stage Sound Classification Network,” Transactions of KSAE, Vol.30, No.2, pp.161-169, 2022.
- 7) C. Lessmeier, J. K. Kimotho, D. Zimmer and W. Sextro, “Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification,” PHM Society European Conference, Bilbao, Spain, pp.1-17, 2016.
- 8) Z. Wang, W. Zhao, W. Du, N. Li and J. Wang, “Data-Driven Fault Diagnosis Method Based on the Conversion of Erosion Operation Signals into Images and Convolutional Neural Network,” Process Safety and Environmental Protection, Vo.149, pp.591-601, 2021.
- 9) N. Mehala and R. Dahiya, “A Comparative Study of FFT, STFT and Wavelet Techniques for Induction Machine Fault Diagnostic Analysis,” Proceedings of the 7th WSEAS International Conference on Computational Intelligence, Man-Machine Systems and Cybernetics, Vol.2931, pp.203-208, 2008.
- 10) K. He, X. Zhang, S. Ren and J. Sun, “Deep Residual Learning for Image Recognition,” Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp.770-778, 2016.